

This is a postprint version of the following published document:

Piol, A., et al. (2020, noviembre). *Método de reconstrucción tomográfica con información a priori obtenida con aprendizaje profundo*. En: CASEIB 2020: XXXVIII Congreso Anual de la Sociedad Española de Ingeniería Biomédica, libro de actas, 25–27 Nov, 2020. Sociedad Española de Ingeniería Biomédica, 2020, pp. 206–209.

URL: [http://caseib.es/2020/wp-content/uploads/2020/12/CASEIB2020\\_LibroActas.pdf](http://caseib.es/2020/wp-content/uploads/2020/12/CASEIB2020_LibroActas.pdf)



This work is licensed under a [Se distribuye bajo una licencia de Creative Commons Reconocimiento-NoComercial-SinObraDerivada 4.0 Internacional.](https://creativecommons.org/licenses/by-nc-nd/4.0/)

# Método de reconstrucción tomográfica con información a priori obtenida con aprendizaje profundo

A. Piol<sup>1,2</sup>, C. F. del Cerro<sup>1,2</sup>, J. García-Blas<sup>3</sup>, M. Desco<sup>1,2,4,5</sup>, M. Abella<sup>1,2,5</sup>

<sup>1</sup> Departamento de Bioingeniería e Ingeniería Aeroespacial, Universidad Carlos III, Madrid, Spain

<sup>2</sup> Instituto de Investigación Sanitaria Gregorio Marañón (IiSGM), Madrid, Spain

<sup>3</sup> Departamento de Informática, Universidad Carlos III de Madrid, Madrid, España

<sup>4</sup> Centro de Investigación en Red de Salud Mental (CIBERSAM, CIBER CB07/09/0031), 28007 Madrid, Spain

<sup>5</sup> Centro Nacional de Investigaciones Cardiovasculares Carlos III (CNIC), Madrid, Spain

## Resumen

En sistemas de tomografía computarizada tradicionales, los datos se adquieren girando fuente y detector alrededor de la muestra completando un rango angular de 360 grados y obteniendo, generalmente, más de 360 proyecciones. Sin embargo, existen situaciones donde solo es posible obtener un número limitado de proyecciones, como en el caso del uso de sistemas de arco en C en un entorno intraoperatorio. Esta limitación de datos resulta en artefactos específicos en la reconstrucción y, consecuentemente, en pérdida de detalles importantes para el diagnóstico clínico. Una solución para compensar la falta de datos es utilizar información a priori en algoritmos iterativos. El algoritmo SCoLD permite la reconstrucción del volumen con un número limitado de proyecciones, incorporando como información a priori el soporte de la muestra, identificado con una máscara binaria.


En este trabajo se propone una metodología de reconstrucción de datos incompletos basado en la combinación de un algoritmo de reconstrucción que incorpora el soporte de la muestra como información a priori con un paso de obtención de este soporte usando metodología de aprendizaje profundo.

## 1. Introducción

En sistemas de tomografía computarizada, el par fuente-detector gira simultáneamente alrededor del paciente, cubriendo generalmente 360 grados, adquiriendo un conjunto de proyecciones (radiografías planas) desde diferentes posiciones angulares. Cuando el conjunto de proyecciones cumple determinados requisitos, de número y rango angular, la reconstrucción del volumen bajo análisis se puede hacer utilizando algoritmos tradicionales basados en retroproyección filtrada [1]. Sin embargo, existen diferentes situaciones en las que el número de proyecciones adquiridas no alcanza el mínimo para poder utilizar estos algoritmos. Un ejemplo es el uso de arcos en C para obtener imagen tomográfica en quirófano, que presentan limitaciones mecánicas que no permite cubrir todo el rango angular. Otro caso de limitación de datos es la selección de un paso angular grande como medio para reducir las dosis de radiación. En estos casos, el resultado de reconstrucciones con algoritmos convencionales basado en FDK está afectado por dos tipos de artefactos: rayas, en el caso de un paso angular demasiado grande, y distorsión de los bordes, en el caso de un rango angular limitado.

Una forma de compensar la falta de datos es la incorporación de información a priori en algoritmos

iterativos. Ejemplos de información a priori son la positividad de la solución o la característica de homogeneidad de los tejidos. Esta última característica se puede conseguir con métodos de regularización basados en la función de Total Variation (TV) [2-4]. Sin embargo, regularizar con la función TV no soluciona los artefactos causados por un rango angular limitado. Para estos casos, se ha propuesto incorporar como información previa una reconstrucción con datos completos. En [5], se utiliza una reconstrucción con datos completos del mismo paciente en un estudio con *gating* respiratorio, obtenida a partir de las proyecciones de las diferentes fases respiratorias. Una alternativa que se ha propuesto para la reconstrucción de datos limitados en rayos X se basa en técnicas de aprendizaje profundo [6, 7]. Estos trabajos tienen limitaciones en resolución espacial, con un tamaño máximo de imagen de 256×256 píxeles. Por otra parte, para evitar sesgos que resulten en estructuras en la imagen final que realmente no están presentes en los datos, es necesario disponer de una base de datos reales grande. Otra información a priori que se ha propuesto en la literatura es la restricción del espacio de búsqueda de la solución en un determinado área del campo de visión en la que sabemos que se encuentra la muestra. En [8], se presenta *Support-Constraint Limited Data* (SCoLD), un algoritmo de reconstrucción que utiliza el contorno de la muestra para definir la región de búsqueda de la solución. La Figura 1 muestra en ejemplo de resultados aplicando el algoritmo SCoLD a un conjunto de datos de 70 proyecciones en un rango angular de 140 grados, que permite reducir los artefactos y alcanzar una calidad de imagen muy parecida a la de un TAC estándar (360 proyecciones con 360 grados de rango angular).



**Figura 1:** Corte axial de un estudio de datos limitados de un pequeño animal reconstruido con FDK (izquierda) y SCoLD (centro). Reconstrucción con datos completos utilizando algoritmo FDK (derecha).

En [8], el contorno de la muestra se obtiene mediante un escáner de superficie. La adquisición de esta superficie

puede complicar el protocolo clínico e incluso ser imposible por la existencia de tejido cubriendo al paciente. En este trabajo se propone eliminar los problemas derivados del uso de dispositivos externos obteniendo este contorno por medio de técnicas de aprendizaje profundo.

## 2. Método propuesto

El método propuesto consiste en tres pasos: (1) reconstrucción preliminar con FDK, que será la entrada a la red, (2) obtención de la máscara binaria que define el soporte de la muestra con la red y (3) uso de esta máscara en SCoLD para obtener la reconstrucción final sin artefactos.

Para la obtención de la máscara, se utiliza U-net, red propuesta para segmentación en [9], con el Error Cuadrático Medio (MSE) como función de coste. Como parámetros de entrenamiento se utilizan una tasa de aprendizaje de  $10^{-3}$  durante 40 épocas y el optimizador Adam [10]. Los datos de entrada de la red son cortes 2D de tamaño  $256 \times 256 \times 1$ . Para el proceso de entrenamiento y validación del modelo se ha utilizado Python (versión 3.8). La Figura 2 muestra un esquema de la arquitectura de la red utilizada.

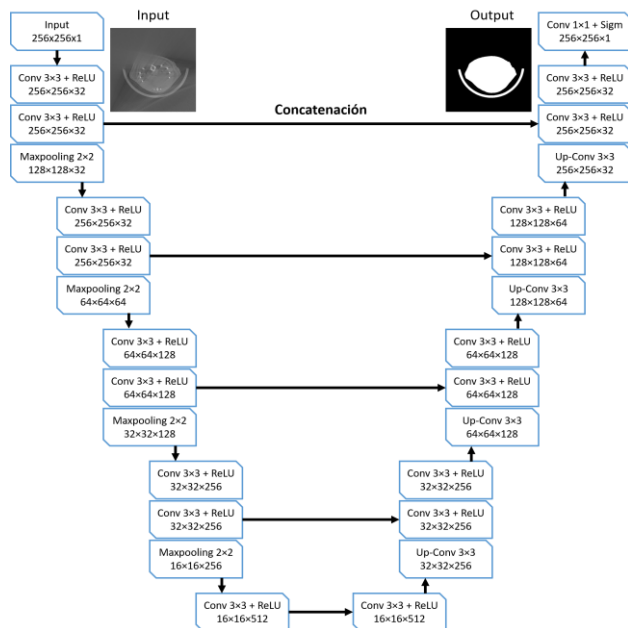


Figura 2: Arquitectura de la red utilizada.

Para poder utilizar la máscara binaria en el algoritmo SCoLD, las imágenes en salida a la red se redimensionan al tamaño de la reconstrucción.

## 3. Generación de la base de datos

La base de datos para el entrenamiento del modelo se ha creado a partir de cuatro estudios de roedor adquiridos con el sistema micro CT Add-on de SEDECAL [11]. Cada estudio está formado por 360 proyecciones de  $768 \times 486$  píxeles obtenidas en un rango angular de 360 grados, distribuidas uniformemente. La máscara ideal se ha obtenido por umbralización en la reconstrucción de los datos completos con un método basado en FDK [12], un volumen de tamaño  $768 \times 768 \times 486$ .

Se han simulado con FuxSim [13] cuatro estudios eliminando proyecciones de manera aleatoria para cada uno de los siguientes escenarios de datos limitados (Figura 3): (1) Rango angular limitado, (2) número de proyecciones limitado y (3) rango angular y número de proyecciones limitados.




Figura 3: Esquema de selección de rango angular y proyecciones para los casos de rango angular limitado (A), número de proyecciones limitado (B) y rango angular y número de proyecciones limitados (C).

El conjunto de datos está compuesto por los cortes centrales de cada estudio, obteniendo un total de 8904 imágenes, separados en 6410 para entrenamiento y 1781 para validación. Dado que lo que esperamos obtener de la red es información paso bajo (la máscara soporte del objeto), estas imágenes se han submuestreado al tamaño de  $256 \times 256$ .

La Figura 4 muestra ejemplos de cortes para cada escenario de datos limitados junto a la reconstrucción de referencia.




Figura 4: Corte axial central de la reconstrucción FDK de datos completos (A), datos con un número de proyecciones limitado (B), datos con rango angular limitado (C), datos con número de proyecciones y rango angular limitados (D).

## 4. Evaluación y Resultados

Para evaluar la calidad de la máscara obtenida se ha utilizado el coeficiente de Dice-Sørensen (DSC) con respecto a la máscara ideal:


$$DSC = \frac{2 \cdot |X \cap Y|}{|X| + |Y|} \quad (1)$$

donde X y Y son los dos volúmenes binarios de comparar.

Los datos limitados se han reconstruido con FDK, con SCoLD incorporando la máscara obtenida por umbralización, con SCoLD utilizando la máscara ideal y con el método propuesto.


Para evaluar el efecto en la reconstrucción final de la máscara utilizada como información a priori, se ha calculado la raíz del error cuadrático medio (RMSE) entre FDK con datos completos (referencia) y todas las reconstrucciones obtenidas con SCoLD, con las diferentes máscaras. Se presentan resultados en dos estudios representativos: (1) rango angular de 130 grados, con un paso angular de 1 grado y (2) rango angular de 140 grados, con un paso angular de 2 grados (70 proyecciones totales).

La Figura 5 muestra el caso de rango angular de 130 grados y paso angular de 1 grado. Se puede ver la distorsión de los bordes en la parte superior izquierda de la reconstrucción de datos limitados, que se reflejan en la máscara obtenida por umbralización. La máscara obtenida con la red propuesta elimina estos artefactos en los bordes y permite una cama está bien definida y separada de la muestra, como ocurre en la máscara ideal.



**Figura 5:** Corte axial de la reconstrucción FDK de datos limitados (A), máscara ideal (B), máscara obtenida por umbralización (C) y máscara obtenida del método propuesto. Rango angular de 130 grados y paso angular de 1 grado.


La Figura 6 muestra el caso de rango angular de 140 grados y paso angular de 2 grados (70 proyecciones).



**Figura 6:** Corte axial de la reconstrucción FDK de datos limitados (A), máscara ideal (B), máscara obtenida por umbralización (C) y máscara obtenida con el método propuesto. Rango angular de 140 grados y paso angular de 2 grados.

La máscara obtenida por umbralización a partir de la reconstrucción con FDK muestra la distorsión de los bordes en la parte arriba-izquierda y en la inferior derecha y los artefactos de rayas de la reconstrucción FDK de datos limitados. Estos artefactos se eliminan con el método propuesto, quedando la cama bien definida y separada de la muestra, como ocurre en la máscara ideal.

La Figura 7 muestra los resultados de las reconstrucciones con SCoLD, donde se puede ver como el método propuesto elimina los artefactos de distorsión de bordes, obteniendo un resultado similar al de SCoLD + máscara ideal.



**Figura 7:** Izquierda: estudio con 130 grados de rango angular, reconstruido con FDK (A), SCoLD + máscara ideal (B), SCoLD + máscara por umbralización (C) y método propuesto (D). Derecha: estudio con 140 grados de rango angular y 2 grados de paso angular reconstruida con FDK (E), SCoLD + máscara ideal (F), SCoLD + máscara datos limitados (G) y método propuesto (H).

La Tabla I muestra coeficientes de DICE cercanos a 1 y un valor de RMSE inferior para el método propuesto.

	Rango 130°, paso 1°	Rango 140°, paso 2°
DICE	0.993	0.995
RMSE	267	332.40
SCOLD + umbralización	164.37	165.33
Método propuesto	156.56	159.15

## 5. Discusión y conclusiones

Este trabajo presenta una metodología de reconstrucción de datos incompletos basado en la combinación de SCoLD, un algoritmo de reconstrucción que incorpora el soporte de la muestra como información a priori, con un paso de obtención de este soporte usando metodología de aprendizaje profundo. En trabajos previos, este soporte se obtenía con un escáner de superficie, no siempre posible por la presencia de ropa o sábanas tapando al paciente y suponiendo una dificultad extra a proceso de adquisición. El método propuesto, además de eliminar la necesidad de este paso de adquisición de la superficie, resulta en una superficie ajustada a la información de rayos X, evitando diferencias debidas al uso de otros tipos de radiación para la adquisición de la superficie.

La evaluación preliminar sobre simulaciones a partir de proyecciones reales, cubriendo diferentes escenarios de datos limitados, muestra la viabilidad de la propuesta. En todos los casos analizados, la máscara obtenida se corresponde con la ideal obtenida por umbralización a partir del estudio de alta dosis. El método propuesto reduce el RMSE en 41.36% para el caso 130 de rango angular y 52.12%, para el caso 140 de rango angular con respecto a la reconstrucción FDK con datos limitados. En ambos estudios, la máscara obtenida por umbralización desde la reconstrucción con datos limitados, lleva a un peor resultado con respecto al método propuesto: el método propuesto reduce el RMSE en un 5.12% para el caso de 130 grados de rango angular y en 3.77% para el caso de 140 grados de rango angular.

Sin embargo, el uso de métodos híbridos como el propuesto, que incluye un paso de reconstrucción iterativa, comporta tiempos de ejecución altos. Como trabajo futuro, se estudiará una metodología que elimine el paso de reconstrucción iterativa, obteniendo de la red directamente la imagen procesada. Para ello, será necesario resolver los problemas de resolución espacial y optimizar la fase de entrenamiento para evitar el sobreentrenamiento.

## Agradecimientos

Este trabajo ha sido financiado por el Ministerio de Ciencia, Innovación y Universidades (Instituto de Salud Carlos III, proyecto DTS17/00122; Agencia Estatal de Investigación, proyecto DPI2016-79075-R-AEI/FEDER, UE), cofinanciado por Fondos de la Unión Europea (FEDER), "A way of making Europe". Además, ha sido financiado por el Programa de apoyo a la realización de proyectos interdisciplinarios de I+D para jóvenes investigadores de la Universidad Carlos III de Madrid 2019-2020 en el marco del Convenio Plurianual

Comunidad de Madrid- Universidad Carlos III de Madrid (proyecto DEEPCT-CM-UC3M) y por CRUE Universidades, CSIC y el Banco Santander (Fondo Supera, proyecto RADCOV19). El CNIC está financiado por el Ministerio de Ciencia, Innovación y Universidades y la fundación PRO-CNIC y es un centro de excelencia Severo Ochoa (SEV-2015-0505).

## Referencias

- [1] L. A. Feldkamp, L. C. Davis, and J. W. Kress, "Practical cone-beam algorithm," *J. Opt. Soc. Amer.*, vol. 10, pp. 612–619, 1984.
- [2] E. Y. Sidky and X. Pan, "Image reconstruction in circular cone-beam computed tomography by constrained, total-variation minimization," *Phys Med Biol*, vol. 53, pp. 4777–4807, 2008.
- [3] E. Y. Sidky, C. M. Kao, and X. Pan, "Accurate image reconstruction from few-views and limited-angle data in divergent-beam CT," *Journal of X-ray Science and Technology*, vol. 14, pp. 119–139, 2006.
- [4] M. Chang, L. Li, Z. Chen, Y. Xiao, L. Zhang, and G. Wang, "A few-view reweighted sparsity hunting (FRESH) method for CT image reconstruction," *J Xray Sci Technol*, vol. 21, pp. 161–176, 2013.
- [5] F. P. J. Abascal, M. Abella, E. Marinetto, J. Pascau, and M. Desco, "A novel prior- and motion-based compressed sensing method for small-animal respiratory gated CT," *PLoS One*, vol. 11, p. e0149841, 2016.
- [6] H. Zhang, L. Li, K. Qiao, L. Wang, B. Yan, L. Li, *et al.*, "Image prediction for limited-angle tomography via deep learning with convolutional neural network," *arXiv preprint arXiv:1607.08707*, 2016.
- [7] Y. Huang, S. Wang, Y. Guan, and A. Maier, "Limited angle tomography for transmission X-ray microscopy using deep learning," *Journal of Synchrotron Radiation*, vol. 27, 2020.
- [8] M. Monica Abella, C. de Molina, N. Ballesteros, A. García-Santos, A. Martínez, I. García, *et al.*, "Enabling tomography with low-cost C-arm systems," *Plos One*, vol. 13, p. e0203817, 2018.
- [9] M. Buda, A. Saha, and M. A. Mazurowski, "Association of genomic subtypes of lower-grade gliomas with shape features automatically extracted by a deep learning algorithm," *Computers in biology and medicine*, vol. 109, pp. 218–225, 2019.
- [10] D. P. Kingma and J. Ba, "Adam: A method for stochastic optimization," *arXiv preprint arXiv:1412.6980*, 2014.
- [11] J. J. Vaquero, S. Redondo, E. Lage, M. Abella, A. Sisniega, G. Tapias, *et al.*, "Assessment of a New High-Performance Small- Animal X-ray Tomograph," *IEEE Trans Nucl Sci*, vol. 55, pp. 898–905, 2008.
- [12] M. Abella, J. J. Vaquero, A. Sisniega, J. Pascau, A. Udías, V. García, *et al.*, "Software architecture for multi-bed FDK-based reconstruction in X-ray CT scanners," *Computer methods and programs in biomedicine*, vol. 107, pp. 218–232, 2012.
- [13] M. Abella, E. Serrano, J. Garcia-Blas, I. García, C. De Molina, J. Carretero, *et al.*, "FUX-Sim: Implementation of a fast universal simulation/reconstruction framework for X-ray systems," *Plos one*, vol. 12, p. e0180363, 2017.